

Faculdade de Engenharia da Universidade do Porto



Identificação de regiões nodulares em imagens digitais de radiografia pulmonar

Lúcio Orlando Mourão Alves

Dissertação realizada no âmbito do
Mestrado Integrado em Engenharia Electrotécnica e de Computadores
Major Telecomunicações

Orientador: Prof.^a Dr.^a Ana Maria Mendonça
Co-orientador: Prof. Dr. António Sousa

Julho de 2009

Resumo

Nesta dissertação é apresentado um sistema para a identificação de regiões nodulares em imagens digitais de radiografia pulmonar usando, para tal, algoritmos previamente desenvolvidos [1] que foram estendidos através da inclusão de um sistema de classificação tendo por objectivo a redução do número de falsos positivos detectados na primeira fase.

Atendendo à forma dos nódulos, começa-se por usar um filtro de realce, tendo sido seleccionado para esse fim um filtro de convergência, designado filtro de banda deslizante (SBF - *sliding band filter*). Este filtro tem uma resposta mais alta quando o ponto em análise está mais próximo do centro de uma região circular de intensidade superior à do respectivo fundo. Na imagem realçada, as regiões nodulares estão associadas a valores mais elevados comparativamente ao resto da imagem. De modo a reduzir a influência dos vasos sanguíneos perto do mediastino, a imagem filtrada é multiplicada por uma máscara de probabilidade. De seguida, é aplicada, na imagem resultante, uma transformada *watershed*, que divide cada pulmão numa série de regiões não sobrepostas, ficando o máximo de cada região associado a uma localização de um potencial nódulo. Como extensão do trabalho, são também incluídas as regiões do pulmão escondidas por outras estruturas anatómicas, entre elas o diafragma e o mediastino, dado que 14 das imagens contêm nódulos fora das máscaras estabelecidas no trabalho inicial. Posteriormente, é extraído um conjunto de características para dar entrada num classificador e validar cada uma das regiões candidatas, tendo em vista a redução do número de falsos positivos.

Abstract

This thesis presents a system for the identification of nodular regions in digital images of pulmonary radiograph using previously developed algorithms [1] upgraded through the inclusion of a classification system. The goal of the classification system is to reduce the number of false positives detected on the first phase.

Regarding the shape of the nodules, we begin by using an enhancement filter, more specifically a convergence filter, named Sliding Band Filter (SBF). This filter tends to have a higher response as the point being analysed is closer to the centre of the circular region with higher intensity than its background. In the enhanced image, the nodular regions are associated to higher values comparatively to the rest of the image. With the goal of reducing the influence of the blood vessels near the mediastinum, the enhanced image is multiplied by a probability mask. Then a watershed transform is applied on the resulting image for dividing each lung into a set of non-overlapping regions, associating the local maximum values of each region to a nodule location. As an extension of the work, lung regions hidden by other anatomic structures, such as the diaphragm and the mediastinum, were also included, since 14 of the images have nodules out of the established mask of the initial work. Afterwards, a set of characteristics is extracted and imputed to a classifier so that it validates each on the candidate regions in order to reduce the number of the false positives.

Agradecimentos

Gostaria de agradecer, de modo especial, à minha orientadora, Professora Ana Maria Mendonça, e ao meu co-orientador, Professor António Sousa, toda a ajuda prestada durante a realização deste trabalho.

Gostaria ainda de agradecer o apoio prestado pelo Rui Caldeira e pelo Christophe Silva, que também desenvolveram os seus trabalhos no INEB.

Índice

Resumo	iii
Abstract	v
Agradecimentos	vii
Índice	ix
Lista de figuras	xi
Lista de tabelas	xiii
Abreviaturas e símbolos	xv
Capítulo 1 - Introdução	1
1.1. - Motivação	1
1.2. - Estrutura da dissertação	2
1.3. - Breve descrição do sistema	2
Capítulo 2 - Revisão bibliográfica	3
2.1. - Introdução	3
2.2. - Revisão bibliográfica	3
Capítulo 3 - Metodologia	11
3.1. - Introdução	11
3.2. - Realce da imagem	11
3.3. - Detecção de regiões candidatas a nódulos pulmonares	14
3.4. - Classificação	18
3.4.1. - Medição de características	18
3.4.2. - Selecção de características	23
3.4.3. - Classificadores	24

3.4.4. - Problema das classes não balanceadas	26
3.4.5. - Avaliação do sistema	26
Capítulo 4 - Resultados	27
4.1. - Introdução	27
4.2. - Base de dados JRST	27
4.3. - Resultados	29
4.3.1. - Realce da imagem	29
4.3.2. - Detecção de regiões candidatas a nódulos pulmonares	30
4.3.3. - Classificação	32
Capítulo 5 - Conclusão	35
Anexo I	37
Referências	47

Lista de figuras

Figura 2.1 - a) imagem actual; b) imagem resultante da subtracção	4
Figura 2.2 - a) imagem actual; b) imagem resultante da subtracção	5
Figura 2.3 - Resultado da detecção de orlas	7
Figura 2.4 - Áreas dos pulmões segmentadas pelo ASM	8
Figura 2.5 - (a) antes e (b) depois da normalização local	9
Figura 3.1 - Filtro de banda deslizante	13
Figura 3.2 - a) imagem original; b) imagem realçada com o filtro de banda deslizante	13
Figura 3.3 - a) máscara original; b) pontos iniciais; c) rectas traçadas; d) preenchimento	14
Figura 3.4 - Máscara da região pulmonar escondida	15
Figura 3.5 - a) linhas paralelas ao eixo de orientação da máscara; b) máscara de probabilidade	16
Figura 3.6 - Máscara de probabilidade aplicada à máscara da região escondida do pulmão	16
Figura 3.7 - a) Resultado da transformada <i>watershed</i> ; b) Resultado final com os lugares dos candidatos a nódulos	17
Figura 3.8 - Pontos para a detecção do novo sistema de coordenadas	19
Figura 3.9 - Novo centro detectado	20
Figura 3.10 - Comparação da superfície de decisão entre o LDC (à esquerda) e o QDC (à direita)	25
Figura 4.1 - Imagem JPCLN004 (pulmão direito)	28
Figura 4.2 - Alguns exemplos de imagens filtradas com o SBF	29
Figura 4.3 - Resultados do processamento para a detecção de regiões nodulares suspeitas usando: a) máscara original b) máscara da região escondida	30
Figura 4.4 - Diagramas <i>scatter</i> de cinco características. As marcas a vermelho	

indacam verdadeiros positivos e as azuis falsos positivos	33
Figura 4.5 - Diagramas <i>scatter</i> de três características. As marcas a vermelho	
indacam verdadeiros positivos e as azuis falsos positivos	33

Lista de tabelas

Tabela 4.1 - Número de nódulos da base de dados relacionando o tamanho e o grau de subtileza	28
Tabela 4.2 - Cor da circunferência relativa à posição encontrada da região	31
Tabela 4.3 - Total de regiões detectadas usando máscara de probabilidade	31
Tabela 4.4 - Total de regiões detectadas não usando máscara de probabilidade	32
Tabela 4.5 - Total de regiões remanescentes após descarte de falsos positivos	32
Tabela 4.6 - Resultados finais dados pela classificação	34
Tabela 4.7 - Resultados finais dados pela classificação	34
Tabela I-1 - Posição da região relativamente ao nódulo verdadeiro usando imagens com nódulos, máscara original e sem máscara de probabilidade	37
Tabela I-2 - Posição da região relativamente ao nódulo verdadeiro usando imagens com nódulos, máscara original e com máscara de probabilidade	38
Tabela I-3 - Posição da região relativamente ao nódulo verdadeiro usando imagens com nódulos, máscara da região escondida e sem máscara de probabilidade	39
Tabela I-4 - Posição da região relativamente ao nódulo verdadeiro usando imagens com nódulos, máscara da região escondida e com máscara de probabilidade	40
Tabela I-5 - Número de regiões detectadas por imagem	40
Tabela I-6 - Valores da função Golub para as características das regiões usando a máscara original	45
Tabela I-7 - Valores da função Golub para as características das regiões usando a máscara da região escondida	46

Abreviaturas e Símbolos

Lista de abreviaturas

ANNs	Artificial Neural Networks
ASM	Active Shape Model
CAD	Computer-Aided Diagnosis
INEB	Instituto de Engenharia Biomédica
JSRT	Japanese Society of Radiological Technology
kNN	k Nearest Neighbours
LDC	Linear Discriminant Classifier
LoG	Laplacian of Gaussian
QDC	Quadratic Discriminant Classifier
SBF	Sliding Band Filter
SVMs	Support Vector Machines

Lista de símbolos

Θ - ângulo

μ - média

σ - desvio padrão

Capítulo 1

Introdução

1.1. - Motivação

Nos dias que correm, apesar da Medicina estar bastante avançada, conseguindo curar grande parte das doenças que há alguns anos atrás destinavam um doente à morte, continua a haver falhas na resolução de enfermidades tais como o cancro, pois a taxa de insucesso é relativamente alta, principalmente quando estas não são detectadas atempadamente, de modo a que possam ser enfrentadas com o tratamento adequado.

Uma parte dos casos de doenças descobertas em estado considerado avançado é resultado de deficientes análises de resultados, pelas mais variadas razões. Para ajudar os profissionais de saúde a obter um diagnóstico mais concreto e objectivo, o processamento de imagem pode ser uma ajuda preciosa. Para tal, ao longo das últimas décadas, vários sistemas de diagnóstico auxiliado por computador (*computer-aided diagnosis* - CAD) têm sido desenvolvidos. A finalidade dos sistemas CAD é melhorar a eficácia do diagnóstico, assim como a consistência da interpretação, neste caso, da radiografia torácica, usando o resultado, gerado automaticamente pelo sistema, como segunda opinião para o especialista. Este resultado pode ser útil, uma vez que o diagnóstico do radiologista é baseado em avaliação subjectiva, estando sujeito a variações intra e interpessoais, bem como à baixa qualidade da imagem, sobreposição de estruturas, fadiga visual ou distracção [2].

O baixo custo e a versatilidade da radiografia fazem com que seja o procedimento mais usado em radiologia. Tem também como vantagem o facto de exigir apenas uma quantidade diminuta de raios-X, quando comparado com um exame de tomografia [3]. Por estas razões, melhoramentos na detecção de nódulos pulmonares em radiografias torácicas poderão ter um impacto significativo na detecção atempada de cancro pulmonar. No entanto, devemos estar cientes das dificuldades relacionadas com esta detecção pois os nódulos têm

uma enorme gama de tamanhos e densidades e, além disto, podem encontrar-se em zonas onde estão “escondidos” por outras estruturas anatómicas [4].

1.2. - Estrutura da dissertação

Esta dissertação é composta por 5 capítulos, incluindo este capítulo de introdução. No capítulo 2 é apresentada a revisão bibliográfica feita. No capítulo 3 faz-se uma descrição da metodologia. No capítulo 4 mostram-se os resultados e no capítulo 5 são apresentadas as principais conclusões do trabalho.

1.3. - Breve descrição do sistema

Inicialmente, a imagem de raios-X é filtrada usando um Filtro de Banda Deslizante. Este filtro foi usado para o realce da imagem e, conseqüentemente, das regiões suspeitas. Ao resultado da filtragem foi multiplicada uma máscara de probabilidade, de modo a reduzir a influência dos vasos sanguíneos perto do mediastino, pois estes aparecem na radiografia com aspecto mais claro, levando a que a resposta do filtro seja mais alta, falseando resultados. Na imagem resultante, é aplicada uma transformada *watershed* dividindo, assim, cada pulmão em regiões não sobrepostas, ficando o máximo de cada região associado a uma localização de um potencial nódulo. Este sistema foi previamente desenvolvido por Pereira *et al.* [1] e tinha como objectivo identificar as regiões suspeitas na imagem de raios-X de acordo com os valores máximos da imagem filtrada mas apenas na parte visível dos pulmões. No trabalho desenvolvido no âmbito desta dissertação, é também implementada a possibilidade de identificar regiões nas áreas escondidas. Apesar do procedimento ser igual para os dois casos, foram sempre tratados separadamente, pelo facto das características das duas regiões serem completamente distintas.

Na etapa seguinte, extracção de características, é calculado um conjunto de características de modo a que possam dar ao classificador um conjunto de informação útil acerca das regiões detectadas. O principal objectivo da classificação é descartar o máximo de falsos positivos sem eliminar os verdadeiros nódulos, isto é, reduzir, em termos médios, o número de falsos positivos detectados para cada uma das imagens analisadas.

Capítulo 2

Revisão bibliográfica

2.1. - Introdução

Ao longo dos anos, vários esquemas computadorizados foram propostos para a detecção de nódulos pulmonares em radiografias torácicas digitais. Tipicamente, estes esquemas podem ser divididos em quatro fases, nomeadamente, segmentação da área pulmonar, detecção de regiões candidatas, extração de características das regiões detectadas e, por último, classificação, de modo a reduzir o número de falsos positivos encontrados. Por vezes, existe um pré-processamento antes da detecção de regiões, baseado em realce da imagem ou técnicas de subtração.

2.2. - Revisão bibliográfica

Toriwaki et al. [5] usaram, em 1973, uma abordagem baseada na detecção de orlas com um filtro linear para localizar regiões suspeitas. Posteriormente, realizaram uma série de testes para o tamanho, localização e variação da densidade para examinar essas regiões. Lampeter e Wandtke [6], em 1986, manualmente mascararam a parte externa ao pulmão. Os nódulos eram detectados pelo uso de uma transformada de Hough para circunferências.

Estes trabalhos iniciais em esquemas CAD para a detecção de nódulos basearam-se principalmente na detecção de orlas e realce do contraste. Nenhuma tentativa foi feita para suprimir estruturas de fundo. Giger et al. [7] [8] (1988, 1990) desenvolveram uma técnica de imagem diferencial para reduzir essas estruturas anatómicas complexas, enquanto

evidenciava padrões idênticos a nódulos. Esta técnica de imagem diferencial consiste na subtracção de duas imagens filtradas que foram obtidas a partir da imagem original. O objectivo é remover estruturas nas radiografias torácicas de modo a que anormalidades fiquem mais visíveis. Uma primeira abordagem é a técnica de subtracção temporal, baseada em duas radiografias do mesmo paciente, sendo uma antiga e outra actual. A antiga é subtraída à actual e, caso haja diferenças, estas surgem evidenciadas (figura 2.1).




Figura 2.1 - a) imagem actual; b) imagem resultante da subtracção

No caso de não haver uma radiografia antiga, a subtracção pode ser feita usando a simetria do campo do pulmão esquerdo ou direito, ou seja, a imagem de um pulmão é retirada ao resultado da reflexão do outro. Esta técnica é denominada subtracção contralateral (figura 2.2).




Figura 2.2 - a) imagem actual; b) imagem resultante da subtracção

Este trabalho de Giger *et al.* foi terminado com a produção de duas imagens filtradas a partir de uma única imagem torácica, uma possuindo o sinal realçado dos nódulos e a outra o sinal suprimido. A diferença entre estas duas imagens garantiu uma imagem com o sinal do nódulo sobreposto num fundo simplificado. A imagem resultante foi processada por uma operação de binarização, baseado em histograma. Cada nódulo candidato foi segmentado usando uma técnica de crescimento de regiões. Usando a imagem diferencial e extracção de características, os autores alcançaram uma sensibilidade de 70% com uma média de 7 ou 8 falsos positivos por imagem torácica.

Na tentativa de reduzir o número de falsos positivos, várias abordagens foram investigadas. Em 1992, Matsumoto *et al.* [9] aplicaram técnicas de filtragem linear para produzir imagens de sinal realçado e suprimido. Posteriormente, tentaram reduzir a proeminência de estruturas anatómicas destas imagens. Para a redução de falsos positivos, foram usadas várias características tais como o tamanho, contraste e a forma do candidato, extraídas da imagem diferencial e da original. Nesse estudo, alcançaram uma sensibilidade de aproximadamente 72% e uma taxa de falsos positivos de 5 por imagem, ou seja, relativamente alta.

A investigação de redes neuronais para a redução de falsos positivos foi levada a cabo por Lo *et al.* [10] em 1993. No estudo, seleccionaram 30 pacientes que tiveram cancro com nódulos com tamanhos entre 3 a 15mm e ainda pacientes sem tumores. Primeiramente, realçaram imagens torácicas subtraindo uma imagem com os nódulos suprimidos de uma com os nódulos realçados. A imagem realçada foi então processada por uma técnica de extracção de características depois de usadas as técnicas de detecção de orlas e segmentação da escala de cinzentos. Só então uma rede neuronal é usada para distinguir as costelas e os vasos dos verdadeiros nódulos.

Esquemas CAD mais recentes empregam uma abordagem de três fases, ou seja, selecção inicial dos nódulos candidatos, extracção das características destes candidatos e discriminação dos falsos positivos baseada nestas características. Para melhorar o desempenho da selecção inicial de candidatos, Yoshida *et al.* [11] (1995) usou uma transformada *wavelet* para a detecção de nódulos subtis que passavam despercebidos quando a técnica da imagem diferencial era usada. Nesta abordagem, imagens torácicas digitalizadas são primeiramente decompostas pela transformada *wavelet* e, depois, reconstruídas a partir de componentes de diferentes escalas. Os passos de análise das características foram os mesmos que foram usados na técnica da imagem diferencial. Os resultados deste esquema foram diferentes dos da técnica da imagem diferencial dado que a escala no método de reconstrução parcial foi seleccionada para realçar alguns nódulos subtis que podiam não ser realçados pela técnica de imagem diferencial. Pela combinação da transformada *wavelet* e da técnica de imagem diferencial, os autores aumentaram a sensibilidade para 86% mantendo o mesmo nível de especificidade.

Em 1997, Xu *et al.* [12] desenvolveu um esquema CAD baseado na abordagem das três fases. A técnica da imagem diferencial foi usada no primeiro passo para o realce dos padrões idênticos a nódulos enquanto reduzia as estruturas anatómicas complexas de fundo. Depois da imagem obtida, foi binarizada usando o respectivo histograma para a futura detecção de nódulos candidatos iniciais. Esses nódulos foram então classificados em seis grupos, de acordo com os níveis limiar determinados. Para a separação dos nódulos dos falsos positivos, várias características, principalmente morfológicas, foram extraídas da imagem diferencial e da imagem original, com recurso ao uso de crescimento de regiões e análise do gradiente da orla. Finalmente, uma análise baseada em regras foi aplicada aos candidatos de cada grupo. O esquema CAD alcançou uma sensibilidade de 70% e uma taxa de 2 falsos positivos por imagem.

Baseado na combinação de características morfológicas e na *wavelet snake*, Keserci *et al.* [13] desenvolveu, em 2002, um esquema CAD que consistia na aplicação de 2 processos em paralelo para a redução de falsos positivos depois da selecção inicial de candidatos. Um dos processos consistia na filtragem adaptativa para realce de nódulos e supressão de estruturas de um pulmão normal, seguido de extracção de características morfológicas. O outro processo consistia na eliminação de falsos positivos chamado modelo *wavelet snake* orientado a orlas. Para a determinação do campo pulmonar, os autores identificaram primeiramente a região cardíaca e os limites da caixa torácica. A delimitação da caixa torácica foi usada para extrair a região pulmonar. Seguidamente, identificaram a linha central do tórax determinando uma linha recta que divide o tórax em aproximadamente duas partes simétricas. Para a eliminação do mediastino, foram removidos os pontos que se localizavam à distância de 14mm a partir da linha central. Para a classificação, foram usadas ANNs (*artificial neural networks* - redes neuronais artificiais). Este método da aplicação dos

dois processos em paralelo provou um melhoramento no desempenho na detecção de nódulos pulmonares.

Em 2004, Campadelli *et al.* [14], apresentou um modelo que começava por produzir uma segmentação precisa da área dos pulmões. Esta segmentação incluiu as partes dos pulmões escondidas atrás do coração e diafragma, que são geralmente excluídas por outros métodos. Para a detecção do contorno, foram então usadas duas técnicas de detecção de orlas. A primeira foi baseada na aplicação das primeiras derivadas de filtros gaussianos. A segunda foi baseada na aplicação do método LoG (*Laplacian of Gaussian* - Laplaciano do Gaussiano). Os resultados obtidos por ambas as técnicas foram usados por um algoritmo de detecção de orlas que criava um bom contorno de cada pulmão (figura 2.3).




Figura 2.3 - Resultado da detecção de orlas

Para evidenciar os nódulos de diferentes tamanhos e intensidades, foi usada uma abordagem multi-escala, ou seja, foram produzidas várias imagens, usando a convolução da imagem original com filtros gaussianos. Posteriormente, foram obtidas imagens diferenciais, resultantes da subtração das imagens obtidas anteriormente a partir da imagem original. Neste trabalho não foi utilizado qualquer classificador.

Dois anos mais tarde, em 2006, os mesmos autores [15], no intuito de reduzir o alto número de falsos positivos, usaram SVMs (*support vector machines* - máquinas de suporte vectorial), que foram treinados com múltiplos parâmetros para reconhecer nódulos verdadeiros. Neste esquema, foram obtidos 1,5 falsos positivos por imagem com uma sensibilidade aproximadamente igual a 71%, aumentando para 2,5 e 4 falsos positivos com sensibilidade de aproximadamente 78% e 85%, respectivamente. Para a máxima sensibilidade, 92% e 100%, foram obtidos 7 e 8 falsos positivos, respectivamente.

Neste mesmo ano, Schilham *et al.* [4] apresentaram um modelo para a detecção de nódulos em radiografias torácicas que consistia em 4 passos: pré-processamento da imagem, detecção de nódulos candidatos, extracção de características e classificação dos candidatos. Além destes, foram testadas a selecção e a segmentação de candidatos, apesar de não terem contribuído para um melhor desempenho do modelo. No primeiro passo, pré-processamento da imagem, foi utilizado um ASM (*active shape model*) para a segmentação dos pulmões, requerendo imagens de treino previamente segmentadas (figura 2.4). Este esquema não incluiu a detecção de nódulos nas partes escondidas pelo coração, mediastino e diafragma, tal como aconteceu no modelo apresentado por Campadelli *et al.*



Figura 2.4 - Áreas dos pulmões segmentadas pelo ASM

No intuito de evidenciar os nódulos, foi aplicada uma normalização local, que efectua uma igualização do contraste na imagem (figura 2.5). Para a detecção de regiões candidatas a nódulos e, dado que os nódulos aparecem com diferentes tamanhos, foi empregue o algoritmo de Lindeberg para lidar com este problema, cujo objectivo é encontrar manchas de maior intensidade, ou seja, as regiões mais claras da imagem. Na extracção de características, foi usado um banco de filtros Guassianos multi-escala. Na fase da classificação, para cada candidato, a probabilidade que representa um nódulo foi estimada. O classificador usado foi um kNN (*k nearest neighbours* - k vizinhos mais próximos), que procura o espaço de característica para encontrar os k vizinhos mais próximos da região em avaliação entre todos os nódulos candidatos.




Figura 2.5 - (a) antes e (b) depois da normalização local

Em 2007, Shiraishi *et al.* [16] desenvolveram um esquema computadorizado para a detecção de nódulos pulmonares em vistas laterais de radiografias torácicas. O algoritmo pode ser dividido em 3 partes, designadamente: 1) segmentação dos pulmões, 2) detecção de nódulos e extracção de características da imagem e 3) teste e ANNs. Na primeira parte, a região torácica foi determinada a partir da delimitação entre 20% e 90% do histograma de uma imagem binária, obtida a partir da imagem original. Relativamente à parte 2, as imagens com nódulos realçados foram produzidas através de aplicação de um filtro Gaussiano, de modo a identificar nódulos candidatos. O desempenho do esquema para a detecção de nódulos pulmonares em vistas laterais foi avaliada pelo uso do método *leave-one out*. Neste método, um dos 106 casos de nódulos pulmonares foi testado com a ANN, que foi treinada com os restantes 105 casos. Foi repetido o mesmo procedimento até que os 106 casos fossem validados.

Capítulo 3

Metodologia

3.1. Introdução

Neste capítulo são descritos os métodos utilizados no sistema CAD desenvolvido no âmbito deste trabalho de dissertação. São também referidas as metodologias implementadas no projecto inicial de identificação de regiões candidatas a conterem nódulos pulmonares. O sistema completo é constituído por três partes principais, nomeadamente o realce da imagem de forma a salientar os objectos em estudo, a detecção de regiões candidatas a nódulos pulmonares, onde se realizam algumas operações essenciais tais como o alargamento das máscaras com o contorno dos campos pulmonares usadas no trabalho anterior, a aplicação de uma máscara de probabilidade e da transformada *watershed* e, finalmente, a classificação. Esta fase final é dividida em três secções referentes à medição de características, classificadores e o problema do não balanceamento de dados.

3.2 Realce da imagem

Devido à baixa intensidade de raios-X aplicada ao paciente, as imagens de radiografia torácica são, geralmente, de baixo contraste e com bastante ruído, levando a que os nódulos pulmonares surjam mal evidenciados relativamente ao resto da imagem, influenciando a taxa de sucesso de um sistema CAD. Deste modo, torna-se necessário realçar a imagem de maneira a que os objectos que vão ser alvos de estudo fiquem salientados relativamente ao resto da imagem.

Dado que estes objectos de estudo são aproximadamente circulares e de intensidade superior ao respectivo fundo, optou-se pela utilização de um filtro de convergência, que em trabalhos anteriores se demonstrou ser o mais adequado a este tipo de problema [1] [18].

O filtro seleccionado, denominado filtro de banda deslizante (*sliding band filter* - SBF), pertence à família dos filtros de convergência, dado que se baseia na maximização do coeficiente de convergência.

Se considerarmos um ponto $P(x,y)$, o coeficiente de convergência, $C(x,y)$, é o resultado da média do valor dos cossenos dos ângulos do gradiente calculados em todos os M pontos de uma região R (região de suporte do filtro) como mostrado na equação (3.1)

$$C(x,y) = \frac{1}{M} \sum_{(k,l) \in R} \cos \theta_i(k,l) \quad (3.1)$$

onde θ_i é o ângulo que o vector gradiente faz com o segmento de recta que liga o ponto P com coordenadas (x,y) ao ponto com coordenadas (k,l) .

O que distingue os diversos filtros desta família é, essencialmente, a definição da região de suporte do filtro. Esta região corresponde a N semi-rectas, definidas sobre uma região convexa circular, que irradiam do ponto (x,y) , onde se pretende calcular o valor do resultado da filtragem [1] [17] [18].

Neste trabalho foi usado o filtro de banda deslizante, SBF. Este filtro faz parte da família dos filtros de convergência dado que também se baseia na maximização do coeficiente de convergência. Porém, a característica que o distingue dos outros membros da classe é o facto deste índice ser calculado numa banda de comprimento fixo, mas de posição variável em cada direcção, facilitando uma resposta mais elevada quando as regiões em análise têm uma parte central com nível de convergência mais aleatório do que a respectiva zona exterior, tal como acontece em alguns nódulos pulmonares.

No filtro SBF, para cada uma das N semi-rectas que constituem a região de suporte do filtro, é determinada a posição da banda através do valor de 'n', que maximiza o índice de convergência. Esta posição é determinada numa banda fixa de pontos que se vai movimentando desde o raio mínimo R_{\min} até ao máximo R_{\max} .

A resposta do filtro SBF em cada ponto de coordenadas (x,y) é apresentada na equação (3.2),

$$SBF(x,y) = \frac{1}{N} \sum_{i=0}^{N-1} \left(\max_{R_{\min} \leq n \leq R_{\max}} \left(\frac{1}{d} \sum_{m=n}^{n+d} \cos \theta_{i,m} \right) \right) \quad (3.2)$$

onde ' N ' corresponde ao número de semi-rectas com origem no ponto (x,y) , ' d ' representa a largura da banda, $\theta_{i,m}$ o ângulo formado pelo vector gradiente no ponto ' m ' (distância em pixels do ponto x,y) com a direcção ' i ', e ' R_{\min} ' e ' R_{\max} ' representam, respectivamente, os limites mínimo e máximo possíveis para a localização da banda (figura 3.1).




Figura 3.1 - Filtro de banda deslizante

Na figura 3.2 mostram-se uma imagem original e o resultado do seu realce com recurso ao filtro de banda deslizante.




Figura 3.2 - a) imagem original; b) imagem realçada com o filtro de banda deslizante

3.3. - Detecção de regiões candidatas a nódulos pulmonares

Alguns nódulos pulmonares podem ser encontrados em zonas que estão “escondidas” por outros órgãos, tais como o diafragma, mediastino ou outras estruturas anatómicas. Deste modo, foi efectuada uma alteração às máscaras iniciais contendo o contorno dos campos pulmonares, dado que estas apenas cobriam a parte visível dos pulmões.

De modo a considerar as zonas escondidas, foi criado um algoritmo que actua sobre as máscaras originais (figura 3.3a), detectando dois pontos iniciais, sendo eles o ponto mais próximo do mediastino (assinalado a vermelho na figura 3.3b) e o ponto localizado na posição mais inferior do contorno (assinalado a verde na figura 3.3b) e traçando duas rectas perpendiculares entre si, uma vertical passando pelo ponto do contorno mais próximo do mediastino e outra horizontal passando pelo extremo inferior do contorno (figura 3.3c).

Estas duas rectas constituem os novos limites da máscara contendo o contorno pulmonar a usar no trabalho descrito nesta dissertação.




Figura 3.3 - a) máscara original; b) pontos iniciais; c) rectas traçadas; d) preenchimento

Numa primeira versão deste algoritmo, foram usadas as máscaras alargadas de acordo com o procedimento descrito antes (figura 3.3d). Posteriormente, foi decidido processar separadamente as partes visível e escondida do pulmão por se ter constatado que os valores calculados para as características eram bastante diferentes. Para tal, à máscara alargada foi retirada a original, ficando apenas a área escondida dos pulmões (figura 3.4).



Figura 3.4 - Máscara da região pulmonar escondida

A imagem filtrada resultante do processamento com o filtro da banda deslizante é fortemente influenciada por vasos sanguíneos e brônquios perto do mediastino. De modo a reduzir esta influência, foi decidido atribuir a cada pixel de cada pulmão uma probabilidade P com base na função densidade de probabilidade apresentada na equação (3.3),

$$P(x) = 1 - e^{-ax^n} (1 - p_0) \quad (3.3)$$

onde x é a distância normalizada do pixel à linha paralela ao eixo de orientação do pulmão que fica mais perto do mediastino, $a=10$, $n=4$ e $p_0=0,68$. Estes valores para os parâmetros, que foram estimados a partir de um conjunto aleatório de imagens da base de dados usada neste trabalho e validados nas restantes, têm como objectivo minimizar o número de nódulos não detectados. A normalização da distância é feita com base na largura do pulmão, sendo esta calculada como a distância entre as duas linhas paralelas ao eixo de orientação da máscara pulmonar (figura 3.5a). A máscara de probabilidade calculada para esta imagem exemplo é mostrada na figura 3.5b.




Figura 3.5 - a) linhas paralelas ao eixo de orientação da máscara; b) máscara de probabilidade

Para a distribuição dos valores da probabilidade aos pontos da região escondida, o procedimento adoptado foi o de estender a fórmula definida para a máscara original para a nova máscara alargada. A figura 3.6 ilustra o resultado deste procedimento.



Figura 3.6 - Máscara de probabilidade aplicada à máscara da região escondida do pulmão

As regiões nodulares suspeitas estão associadas com os máximos de intensidade da imagem que resultou do produto da imagem realçada com a máscara de probabilidade. No entanto, como o número de máximos detectados é muito elevado, é aplicada uma transformada *watershed* de modo a segmentar o pulmão em várias áreas não sobrepostas, atribuindo a cada área o máximo de maior intensidade e descartando todos os outros contidos na mesma região segmentada (figura 3.7a). Cada área é então considerada como um potencial candidato a nódulo. Nesta altura, são verificados os valores produzidos pelo filtro de modo a caracterizar a região candidata. A distância que maximiza a resposta do filtro para cada direcção radial dá a indicação da orla da região que, posteriormente, é usada para definir o tamanho provável do nódulo e na extracção de características.

O resultado final é a imagem original onde é assinalado um conjunto de circunferências coloridas, que indicam as respostas mais altas do filtro (figura 3.7b). Cada cor identifica, numa escala definida, o lugar do candidato a conter um nódulo pulmonar. O diâmetro da circunferência é indicativo do tamanho estimado do nódulo.




Figura 3.7 - a) Resultado da transformada *watershed*;
b) Resultado final com os lugares dos candidatos a nódulos

3.4. - Classificação

3.4.1. - Medição de características

O objectivo da medição de características é extrair informação útil para o classificador. Apesar de haver um conjunto vasto de características a serem extraídas, optou-se pela selecção de 9 características geométricas e 12 características de intensidade e contraste, perfazendo um total de 21. Estas características foram escolhidas de acordo com o conhecimento prévio da forma e intensidade dos nódulos e tomando em consideração o trabalho apresentado por Campadelli *et al.* [15].

As características medidas neste trabalho são a seguir apresentadas.

Área normalizada

$$NormArea = \frac{\text{Área da região}}{\pi * r^2}, r = 24 \quad (3.4)$$

O valor de r , estabelecido igual a 24, foi determinado com base na dimensão dos nódulos existentes nas imagens utilizadas durante o trabalho.

A área da região é medida pelo número de *pixels* da região.

Perímetro normalizado

$$NormPerim = \frac{\text{Perímetro da região}}{2 * \pi * r}, r = 24 \quad (3.5)$$

O perímetro da região é o número de pixels da orla da região detectada.

Raio efectivo

O raio efectivo (EffR) é o raio do círculo com uma área equivalente à da região detectada (R_c).

$$EffR = R_c = \sqrt{\frac{\text{Área da região}}{\pi}} \quad (3.6)$$

Coordenadas do centróide da região

$$CCR = \frac{\sum_{i=1}^N P_i}{N} \quad (3.7)$$

onde P_i é o vector posição de cada pixel da região e N é o número total de pixels da região

Coordenadas relativas do centróide

Estas coordenadas são determinadas em relação a um sistema de coordenadas centrado no pulmão. Este novo sistema de coordenadas é determinado calculando a posição de quatro pontos na máscara do pulmão (figura 3.8), sendo eles:

- 1 - Ponto superior (x_1, y_1);
- 2 - Ponto inferior (x_2, y_2);
- 3 - Ponto mais próximo do mediastino (x_3, y_3);
- 4 - Ponto mais afastado do mediastino (x_4, y_4).




Figura 3.8 - Pontos para a detecção do novo sistema de coordenadas
(amarelo - x_1, y_1 ; verde - x_2, y_2 ; azul - x_3, y_3 ; vermelho - x_4, y_4)

O novo centro do sistema de coordenadas é determinado pelas seguintes equações:

$$\begin{aligned}x &= \frac{x_3 - x_4}{2} + x_4 \\y &= \frac{y_1 - y_2}{2} + y_1\end{aligned}\tag{3.8}$$




Figura 3.9 - Novo centro detectado

Circularidade

Definida como a fracção da área da região contida no círculo com a mesma área e centrado no centróide e a área do círculo.

Perímetro efectivo

Definido como o perímetro da região dividido pelo perímetro do círculo com raio igual ao raio efectivo

Coordenadas do centro de massa

As coordenadas são determinadas de acordo com a seguinte expressão:

$$CCM = \frac{\sum_{i=1}^N m_i P_i}{\sum_{i=1}^N m_i} \quad (3.9)$$

onde P_i é o vector posição do *pixel* da região, N o número total de *pixels* e m_i o valor do *pixel* na imagem filtrada.

Distância Euclidiana entre o centro de massa e o centróide da região

Esta distância é determinada através da equação (),

$$d = \sqrt{(CCM_x - CCR_x)^2 + (CCM_y - CCR_y)^2} \quad (3.10)$$

As seguintes características foram calculadas duas vezes por cada região detectada. Da primeira vez são usados os valores da região na imagem original de raios-X e da segunda são usados os valores da região na imagem filtrada.

Média

$$\mu = \frac{\sum_{i=1}^N I_{P(i)}}{N} \quad (3.11)$$

onde I_P corresponde ao valor de intensidade do pixel e N é o número total de *pixels*.

Desvio padrão

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (I_{P(i)} - \mu)^2} \quad (3.12)$$

onde μ corresponde à média da distribuição.

Valor máximo

$$M = \max_{i=1}^N I_{P(i)} \quad (3.13)$$

onde M é o valor máximo encontrado na região.

Contraste

$$\begin{aligned} Mn &= \min_{i=1}^N I_{P(i)} \\ Contr &= M - Mn \end{aligned} \quad (3.14)$$

onde Mn é o valor mínimo encontrado na região. O contraste é determinado pela diferença entre os valores máximo e mínimo.

Média normalizada

$$\mu_N = \frac{\mu}{\max_{j=1}^K M} \quad (3.15)$$

A média normalizada é calculada pelo quociente entre a média da distribuição e o valor máximo encontrado de todas as regiões.

Contraste normalizado

$$Contr_N = \frac{Contr}{\max_{j=1}^K Contr} \quad (3.16)$$

O contraste normalizado é definido pelo contraste da distribuição sobre o valor máximo encontrado de todas as regiões. K define o número de regiões.

Resumo das características

Geométricas:

- Área normalizada;
- Perímetro normalizado;
- Raio efectivo;
- Coordenadas do centróide;
- Coordenadas relativas;
- Circularidade;
- Perímetro efectivo;
- Coordenadas do centro de massa;
- Distância Euclidiana entre o centro de massa e o centróide.

Intensidade e contraste (calculadas sobre as imagens original e filtrada):

- Média;
- Desvio padrão;
- Valor máximo;
- Contraste;
- Média normalizada;
- Contraste normalizado.

3.4.2. - Selecção de características

De maneira a poderem ser escolhidas as melhores características para usar no classificador, foi aplicada uma técnica de selecção de características baseada na estatística univariada de Golub [15] [19]. O resultado desta função pode ser interpretado como a medida de separação entre duas classes, neste caso, nódulos verdadeiros e falsos. Assim, um maior valor, em módulo, desta função para uma determinada característica indica que se pode tratar de uma boa característica. Considerando um problema dicotómico, a estatística de Golub para uma característica i , é formulado de acordo com a equação 3.17,

$$\text{Golub}(i) = \frac{\mu_i^+ - \mu_i^-}{\sigma_i^+ + \sigma_i^-} \quad (3.17)$$

onde μ_i^+ e σ_i^+ representam, respectivamente, a média e o desvio padrão da característica i calculada para os nódulos verdadeiros e μ_i^- e σ_i^- são a média e o desvio padrão calculados para os nódulos falsos.

3.4.3. – Classificadores

A última fase do sistema CAD é a classificação dos candidatos, que tem como objectivo descartar o máximo de falsos positivos mantendo o maior número possível de verdadeiros positivos. Na classificação deste sistema foi utilizado o classificador quadrático pois é um método simples, rápido e robusto que tem mostrado bons resultados na análise de informação complexa [20] [21].

Classificador linear (*Linear discriminant classifier* - LDC)

De acordo com a regra de Bayes, um classificador de erro mínimo é dado pela expressão (3.18):

$$\begin{aligned}\hat{\omega}(x) &= \omega_i \\ i &= \arg \max_{k=1,\dots,C} (P(\omega_k | x)) \\ i &= \arg \max_{k=1,\dots,C} (p(x | \omega_k) P(\omega_k))\end{aligned}\tag{3.18}$$

em que $P(\omega_k | x)$ é a probabilidade a posteriori da amostra x ter sido gerada pela classe ω_k , $p(x | \omega_k)$ é a probabilidade condicionada da amostra sabendo que foi gerada por uma das C classes (função densidade de probabilidade condicionada às classes) e $P(\omega_k)$ a probabilidade a priori da ocorrência da classe. Considerando que todas as classes são normalmente distribuídas, é possível definir expressões analíticas para as funções discriminantes que definem o classificador a partir da probabilidade condicionada (3.19):

$$p(x | \omega_i) = \frac{1}{\sqrt{(2\pi)^d |\Sigma_i|}} \exp \left[-\frac{1}{2} (x - \mu_i)^T \Sigma_i^{-1} (x - \mu_i) \right]\tag{3.19}$$

onde μ_i é a média e Σ_i a matriz de covariância da classe ω_i .

Admitindo que $\Sigma_i = \Sigma$, ou seja, que todas as matrizes de covariância são iguais e substituindo (3.19) em (3.18), o conjunto de funções discriminantes é dada por (3.20):

$$g_i(x) = \left(\log(\lambda(i, j) P(\omega_i)) - \mu_i^T \Sigma_i^{-1} \mu_i \right) + x^T \left(\Sigma_i^{-1} \mu_i \right)\tag{3.20}$$

e que representa uma função de discriminação linear.

Classificador quadrático (*Quadratic discriminant classifier* - QDC)

Tomando em conta o LDC, vamos agora admitir que as matrizes de covariância não são iguais, ou seja, há uma matriz para cada classe. Neste caso, substituindo (3.19) em (3.18), o conjunto de funções discriminantes é dada por:

$$g_i(x) = -\frac{1}{2}(x - \mu_i)^T \Sigma_i^{-1}(x - \mu_i) + \log \lambda(i,j)P(\omega_i) - \frac{1}{2} \log |\Sigma_i| \quad (3.21)$$

Em (3.21) encontra-se a expressão do classificador assim obtido, designado classificador quadrático. As suas superfícies de decisão são “arredondadas”. Estas superfícies dividem as regiões de decisão e encontram-se onde existem “empates” entre duas ou mais categorias. Na figura 3.10 apresentam-se as superfícies de decisão do LDC e do QDC. Pode-se observar que o QDC discrimina melhor a distribuição das amostras de cada classe, pois as curvas acompanham a distribuição.

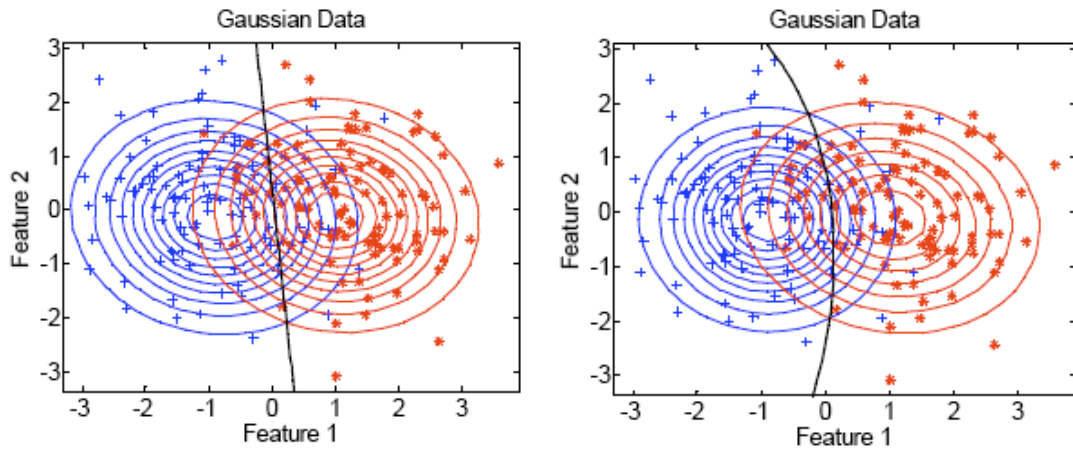


Figura 3.10 - Comparação da superfície de decisão entre o LDC (à esquerda) e o QDC (à direita)

3.4.4. - Problema das classes não balanceadas

Em aplicações médicas, o problema de não balanceamento de dados é frequente e é caracterizado como tendo poucos casos representativos na classe patológica quando comparados com uma população normal.

As soluções mais frequentes para este problema são baseadas em diferentes formas de reamostragem, tais como sobre-amostragem aleatória das classes minoritárias, sub-

amostragem da classe maioritária ou a combinação destas duas soluções. Apesar destas técnicas, há alguns aspectos a ter em conta. A sobre-amostragem da classe minoritária, consistindo na replicação de padrões, pode aumentar o número de más classificações. A sub-amostragem pode resultar em perda de informação. Estes inconvenientes podem ser minimizados pela introdução de ruído na geração de novas amostras das classes minoritárias.

O risco de uma classificação incorrecta pode minimizar-se associando custos aos resultados da classificação e atribuindo valores mais elevados à classificações incorrectas. Esse risco pode ser quantificado pela expressão (3.22),

$$R(\omega_i | x) = \sum_{j=1}^c \lambda(i,j) P(\omega_j | x) \quad (3.22)$$

onde $R(\omega_i | x)$ representa o risco, $\lambda(i,j)$ corresponde ao custo de classificar na classe j uma amostra da classe i e c representa o número de classes.

3.4.5. - Avaliação do sistema

Para a avaliação deste sistema foram utilizados três medidas [15], sendo elas, a sensibilidade (dada pela equação 3.22), a especificidade (equação 3.23) e a exactidão (equação 3.24), aplicadas a todas as imagens utilizadas.

$$\text{Sensibilidade} = \frac{N_{VP}}{N_{VP} + N_{FN}} \quad (3.23)$$

$$\text{Especificidade} = \frac{N_{VN}}{N_{FP} + N_{VN}} \quad (3.24)$$

$$\text{Exactidão} = \frac{N_{VP} + N_{VN}}{N_{VP} + N_{VN} + N_{FP} + N_{FN}} \quad (3.25)$$

Nestas equações 3.22, 3.23 e 3.24, N_{VP} significa o número de verdadeiros positivos, ou seja, o número de regiões suspeitas correctamente etiquetadas como nódulos, N_{FP} corresponde ao número de falsos positivos, ou seja, o número de regiões erradamente etiquetadas como nódulos, N_{VN} significa o número de verdadeiros negativos, ou seja, o número de regiões correctamente etiquetadas como não nódulos e N_{FN} corresponde ao número de falsos negativos, ou seja, o número de regiões erradamente etiquetadas como não nódulos.

Capítulo 4

Resultados

4.1. - Introdução

Neste capítulo são apresentados os resultados das metodologias descritas no capítulo anterior. Primeiramente, é referida alguma informação sobre as imagens usadas no desenvolvimento e validação dos métodos, a base de dados JSRT (*Japanese Society of Radiological Technology*). Seguidamente, são mostrados alguns exemplos de imagens filtradas com o filtro de banda deslizante e os resultados de todo o processamento para a detecção de regiões suspeitas, bem como os resultados do processo de classificação.

4.2. - Base de dados JSRT

Os algoritmos desenvolvidos foram avaliados na base de dados JSRT [22]. Esta base de dados contém 247 imagens de radiografia pulmonar (figura 4.1), das quais 154 são de pacientes com um nódulo pulmonar e 93 são de pacientes sem nódulos.

Esta base de dados inclui, também, informações relativas a cada imagem, nomeadamente:

- Grau de subtileza do nódulo (1 - muito subtil a 5 - óbvio)
- Tamanho do nódulo (em mm)
- Idade do paciente
- Sexo do paciente
- Coordenadas do centro do nódulo

- Classificação do nódulo (maligno ou benigno)
- Localização anatômica do nódulo
- Diagnóstico final (cancro pulmonar, hematoma, abscesso e outros)

Todas as imagens têm 2048x2048 *pixels* e estão representadas com 4096 níveis de cinzento mas, durante este trabalho, foram utilizadas imagens 512x512 com 256 níveis de cinzento de modo a reduzir o esforço computacional. Cada *pixel* corresponde a uma área de 0,7x0,7 mm².

Na tabela 4.1 tem-se uma distribuição dos vários tamanhos dos nódulos comparativamente aos graus de subtileza.

Tabela 4.1 - Número de nódulos da base de dados relacionando o tamanho e o grau de subtileza

Grau de subtileza	Tamanho do nódulo			Total
	Pequeno (<10mm)	Médio (≥10mm e <20mm)	Grande (≥20mm)	
1	2	18	5	25
2	3	16	10	29
3	4	29	17	50
4	1	20	17	38
5	0	5	7	12
Total	10	88	56	154




Figura 4.1 - Imagem JPCLN004 (pulmão direito)

4.3. - Resultados

4.3.1. - Realce da imagem

Todas as imagens foram filtradas com o filtro de banda deslizante, referido no capítulo 3, com os seguintes parâmetros: $R_{\min}=2$, $R_{\max}=21$, $N=256$ e $d=5$. Estes valores foram estabelecidos empiricamente para maximizar a taxa de detecção de regiões. Na figura 5.2 mostram-se alguns exemplos de imagens filtradas com o SBF.




Figura 4.2 - Alguns exemplos de imagens filtradas com o SBF

4.3.2. - Detecção de regiões candidatas a nódulos pulmonares

Depois de todo o processamento para a detecção das regiões suspeitas, são obtidos os resultados da figura 4.3:




Figura 4.3 - Resultados do processamento para a detecção de regiões nodulares suspeitas usando: a) máscara original b) máscara da região escondida

O código de cores das circunferências está definido de acordo com as respostas mais elevadas do filtro, ou seja, para posição 1, o filtro teve a maior resposta e assim sucessivamente (tabela 4.2). A circunferência a branco indica o tamanho e a posição do nódulo verdadeiro.

Tabela 4.2 - Cor da circunferência relativa à posição encontrada da região

Posição do candidato	Cor
1	Azul claro
2	Azul escuro
3	Azul muito escuro
4	Lilás
5	Rosa escuro
6	Vermelho
7	Verde claro
8	Amarelo
9	Laranja
10	Amarelo claro
Acima de 10	Cinzentos

Durante este trabalho também foram determinados os resultados de detecção de regiões suspeitas sem a utilização da máscara de probabilidade. Apesar dos valores serem bastante idênticos, os resultados sem máscara de probabilidades não são tão bons quanto os que foram obtidos com a máscara. Durante toda a análise, verificou-se que sem máscara de probabilidade, a região detectada correspondente ao verdadeiro positivo não tinha tanta sobreposição com o nódulo verdadeiro como com a máscara de probabilidade. Dada esta conclusão, manteve-se a máscara durante o resto do desenvolvimento do trabalho.

Tabelas com a informação da posição detectada do nódulo verdadeiro (com e sem máscara de probabilidades) podem ser consultadas no Anexo I.

Nas tabelas 4.3 e 4.4 apresenta-se uma comparação entre o número de regiões detectadas usando ou não a máscara de probabilidade.

Tabela 4.3 - Total de regiões detectadas usando máscara de probabilidade

Total de regiões detectadas usando máscara de probabilidade	
<i>Máscara</i>	<i>Regiões detectadas</i>
Original	13360
Região escondida	4233

Tabela 4.4 - Total de regiões detectadas não usando máscara de probabilidade

Total de regiões detectadas não usando máscara de probabilidade	
<i>Máscara</i>	<i>Regiões detectadas</i>
Original	13357
Região escondida	4245

4.3.3. - Classificação

De modo a reduzir o número de regiões, foi efectuada uma eliminação preliminar de falsos positivos, através da verificação dos valores máximos e mínimos de algumas características para nódulos verdadeiros. Esta eliminação consiste no descarte de regiões cujas características fiquem abaixo ou acima de valores definidos de acordo com os encontrados para os verdadeiros positivos. A região é descartada se pelo menos uma das características falhar no teste.

Para esta eliminação, foram consideradas todas as características excepto as de posição, isto é, as coordenadas do centróide da região, as coordenadas relativas, as coordenadas do centro de massa e a distância Euclidiana entre o centro de massa e o centróide da região. O número de regiões remanescentes pode ser consultado na tabela 4.5.

Tabela 4.5 - Total de regiões remanescentes após descarte de falsos positivos

Total de regiões remanescentes após descarte de falsos positivos	
<i>Máscara</i>	<i>Regiões remanescentes</i>
Original	10464
Região escondida	555

Os valores da função Golub para as áreas visível e escondida dos pulmões são mostrados na tabela I-6 e I-7 do Anexo I.

A partir dos valores da tabela I-6 e I-7, foram escolhidas as características com maiores valores, em módulo, dado que representam um maior afastamento entre as duas classes (nódulos verdadeiros e falsos positivos).

Na figura 4.4 são mostrados diagramas *scatter* das cinco melhores características escolhidas de acordo com os resultados da função Golub para a máscara original. Estas características são:

- média das imagens original e filtrada;
- valor máximo das imagens original e filtrada;
- média normalizada da imagem original.




Figura 4.4 - Diagramas *scatter* de cinco características. As marcas a vermelho indicam verdadeiros positivos e as azuis falsos positivos

Na figura 4.5 são mostrados diagramas *scatter* das três melhores características escolhidas de acordo com os resultados da função Golub para a máscara da região escondida. Estas características são:

- Coordenada y relativa do centróide;
- Média da imagem filtrada;
- Máximo da imagem filtrada.

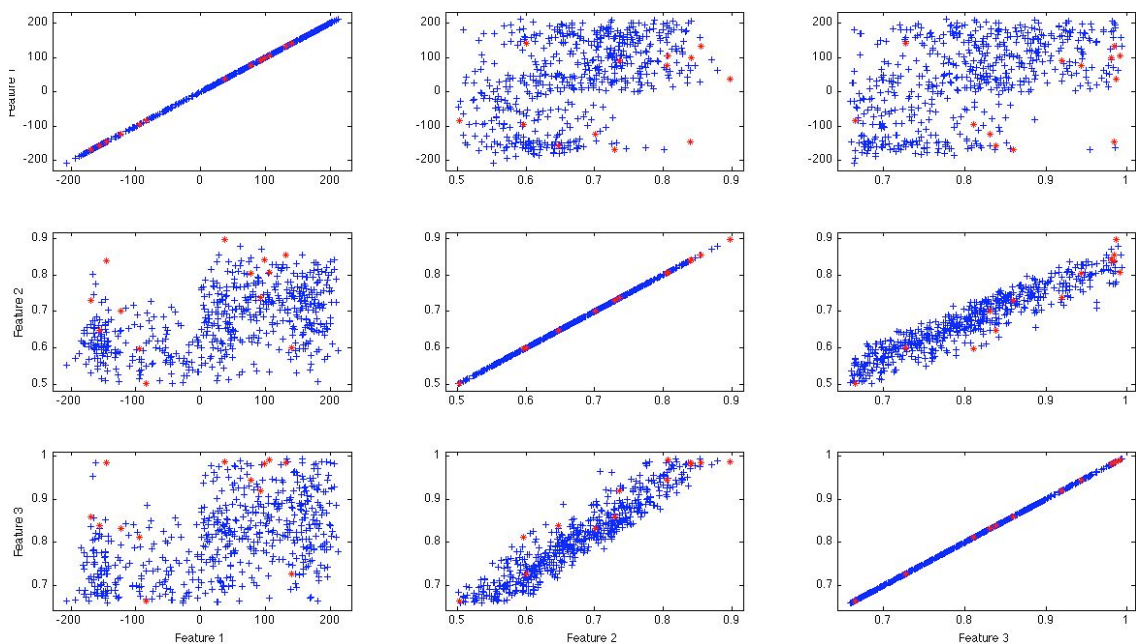


Figura 4.5 - Diagramas *scatter* de três características. As marcas a vermelho indicam verdadeiros positivos e as azuis falsos positivos

A classificação foi realizada usando um classificador quadrático e um conjunto de treino/teste em que o teste continha apenas a imagem a classificar (*leave-one out*), usando para treino todas as outras imagens. Para a definição do classificador para a região visível foi usado o seguinte conjunto de características:

- Média da imagem filtrada e original;
- Máximo da imagem filtrada;
- Média normalizada da imagem filtrada e original;

Para obter os resultados que se apresentam na tabela 4.6 foram utilizados custos distintos para as duas classes, que foram calculados automaticamente usando a função disponível para esse efeito no software utilizado na implementação do classificador (PRTools 4.1.4) e também balanceamento de ambas as classes.

Tabela 4.6 - Resultados finais dados pela classificação

Máscara original	
Número de verdadeiros positivos	102
Número de falsos positivos	1696
Número de verdadeiros negativos	8637
Número de falsos negativos	29

Na classificação dos candidatos na região escondida foram também utilizados custos distintos para as duas classes, sendo que as características seleccionadas foram as seguintes:

- Coordenadas x e y relativas do centróide;
- Média da imagem filtrada;
- Máximo da imagem filtrada.

Tabela 4.7 - Resultados finais dados pela classificação

Máscara da região escondida	
Número de verdadeiros positivos	2
Número de falsos positivos	62
Número de verdadeiros negativos	480
Número de falsos negativos	11

Este sistema atinge uma sensibilidade de 72% com 7 falsos positivos por imagem, sendo que a especificidade e a exactidão são ambas de 84%.

Capítulo 5

Conclusão

Para esta dissertação foi proposta a continuação de um trabalho previamente desenvolvido por Pereira *et al.* [1].

Durante este trabalho, verificou-se que foram detectadas as regiões correspondentes aos nódulos verdadeiros em 131 das 154 imagens nas áreas visíveis do pulmão, o que perfaz uma taxa de detecção de 85%. Com o alargamento das máscaras foi então possível detectar nódulos situados em regiões escondidas, o que aumentou o número de regiões correspondentes aos nódulos verdadeiros para 144, perfazendo uma taxa de detecção de 93,5%. Este alargamento das máscaras iniciais contribui positivamente para o desempenho do sistema. De acordo com a revisão bibliográfica, a maior parte dos sistemas não considera as zonas escondidas dos pulmões. No entanto, 9% dos nódulos encontrados na base de dados localizam-se nestas zonas.

Uma outra conclusão a que se chegou foi que o uso da máscara de probabilidade influencia positivamente o resultado da detecção de nódulos positivos pois o contorno estimado da região é mais aproximado ao real do que sem o uso da máscara de probabilidade.

Foi também concluído que a eliminação preliminar de falsos positivos, através da verificação dos valores máximos e mínimos de algumas características para nódulos verdadeiros, pode ser uma mais-valia do sistema dado que consegue eliminar uma quantia considerável de falsos positivos.

Relativamente à classificação, o sistema conseguiu identificar 104 dos 144 nódulos como sendo verdadeiros, atingindo uma sensibilidade de 72% com 7 falsos positivos por imagem, sendo que a especificidade e a exactidão de 84%. Relativamente aos verdadeiros negativos, o sistema classificou correctamente 9117 entre 11019 regiões.

Para um trabalho futuro, de modo a melhorar o desempenho do sistema, pode-se extrair um novo conjunto de características e utilizar um classificador diferente. Um outro

melhoramento que pode ser implementado é a possibilidade do sistema caracterizar um nódulo como sendo maligno ou benigno.

Anexo I

Seguidamente, são apresentadas tabelas (I-1, I-2, I-3 e I-4) onde se pode verificar a posição atribuída à região que corresponde ao verdadeiro positivo. Na coluna da esquerda está definida a posição, ou seja, para a posição 1, o filtro teve a maior resposta e assim sucessivamente. Na coluna da direita é apresentado o número de nódulos detectados na posição referida na coluna da esquerda.

Tabela I-1 - Posição da região relativamente ao nódulo verdadeiro usando imagens com nódulos, máscara original e sem máscara de probabilidade

Posição da região relativamente ao nódulo verdadeiro usando imagens com nódulos, máscara original e sem máscara de probabilidade	
Posição do nódulo verdadeiro	Número de nódulos
Não detectados dentro das máscaras	9
Não detectados fora das máscaras	14
1	50
2	16
3	12
4	5
5	7
6	6
7	3
8	1
9	4
10	1
11	2
12	2
14	1
15	1
16	2
17	3
19	1
20	1
21	1

22	1
23	1
24	1
27	1
29	1
34	1
35	1
36	2
37	1
39	1
46	1
Total	154

Tabela I-2 - Posição da região relativamente ao nódulo verdadeiro usando imagens com nódulos, máscara original e com máscara de probabilidade

Posição da região relativamente ao nódulo verdadeiro usando imagens com nódulos, máscara original e com máscara de probabilidade	
Posição do nódulo verdadeiro	Número de nódulos
Não detectados dentro das máscaras	9
Não detectados fora das máscaras	14
1	51
2	17
3	10
4	6
5	8
6	4
7	2
9	5
10	1
11	3
12	2
15	2
16	1
17	3
19	1
20	2
21	1
22	1
24	1
25	1

27	1
29	1
35	2
36	2
37	1
39	1
46	1
Total	154

Tabela I-3 - Posição da região relativamente ao nódulo verdadeiro usando imagens com nódulos, máscara da região escondida e sem máscara de probabilidade

Posição da região relativamente ao nódulo verdadeiro usando imagens com nódulos, máscara da região escondida e sem máscara de probabilidade	
Posição do nódulo verdadeiro	Número de nódulos
Não detectados dentro das máscaras	1
Não detectados fora das máscaras	140
1	2
2	2
3	1
4	2
5	1
6	1
9	1
10	1
12	1
14	1
Total	154

Tabela I-4 - Posição da região relativamente ao nódulo verdadeiro usando imagens com nódulos, máscara da região escondida e com máscara de probabilidade

Posição da região relativamente ao nódulo verdadeiro usando imagens com nódulos, máscara da região escondida e com máscara de probabilidade	
Posição do nódulo verdadeiro	Número de nódulos
Não detectados dentro das máscaras	1
Não detectados fora das máscaras	140
1	2
2	2
3	2
4	1
5	1
6	1
9	1
10	1
11	1
14	1
Total	154

Na tabela I-5, é mostrado o número de regiões detectadas em cada imagem. A, B, C e D correspondem, respectivamente, à utilização da máscara original em imagens com nódulos, ao uso de máscara original em imagens sem nódulos, à utilização da máscara da região escondida em imagens com nódulos e ao uso da máscara da região escondida em imagens sem nódulos.

Tabela I-5 - Número de regiões detectadas por imagem

Número de regiões detectadas por imagem				
Imagem	A	B	C	D
1	58	66	13	26
2	44	68	17	24
3	41	40	12	8
4	44	52	11	18
5	36	61	14	25
6	54	49	10	12
7	60	50	14	15
8	58	58	13	20
9	47	57	17	16
10	38	67	17	15

11	55	49	17	14
12	58	57	20	16
13	56	54	20	15
14	51	47	14	23
15	61	41	17	11
16	51	48	21	23
17	55	49	21	11
18	81	44	22	15
19	53	45	17	16
20	63	69	22	12
21	61	47	12	11
22	46	59	19	16
23	49	64	14	23
24	50	37	16	11
25	49	64	20	16
26	59	45	18	16
27	57	43	21	14
28	74	60	24	10
29	40	37	11	12
30	47	47	18	15
31	53	60	17	24
32	62	60	15	22
33	46	60	16	17
34	52	52	17	25
35	65	60	19	23
36	63	55	18	18
37	55	57	20	12
38	40	65	20	22
39	44	62	17	19
40	65	52	22	14
41	43	59	18	19
42	33	68	17	21
43	42	47	17	25
44	44	51	9	20
45	69	83	17	19

46	59	60	16	25
47	70	49	19	21
48	33	58	9	20
49	49	59	16	17
50	46	65	11	17
51	46	52	16	19
52	47	56	13	20
53	73	47	14	13
54	39	74	15	23
55	50	69	12	19
56	44	54	19	23
57	53	52	17	17
58	62	50	18	20
59	47	46	13	16
60	48	58	18	18
61	53	51	18	19
62	43	36	18	17
63	65	56	18	17
64	58	56	20	19
65	47	45	25	24
66	64	45	17	12
67	47	44	16	15
68	56	33	16	10
69	39	65	16	16
70	64	53	13	16
71	45	44	15	14
72	43	50	16	22
73	57	44	20	16
74	68	51	21	22
75	57	57	17	17
76	55	67	14	19
77	59	51	19	20
78	63	50	17	19
79	52	64	14	16
80	47	31	17	10

81	52	70	18	16
82	55	55	15	19
83	62	49	17	16
84	42	43	18	16
85	35	46	9	15
86	71	61	15	21
87	58	43	20	13
88	60	51	17	16
89	69	83	20	20
90	56	56	18	18
91	41	58	20	21
92	70	31	19	12
93	66	50	13	11
94	46		14	
95	35		14	
96	50		17	
97	68		19	
98	63		13	
99	48		16	
100	61		26	
101	63		27	
102	54		17	
103	67		16	
104	70		18	
105	59		20	
106	63		21	
107	91		24	
108	46		16	
109	57		23	
110	50		19	
111	77		17	
112	70		13	
113	50		21	
114	42		17	
115	68		17	

116	51		18	
117	45		21	
118	83		22	
119	41		17	
120	74		23	
121	52		21	
122	53		18	
123	55		20	
124	49		13	
125	50		19	
126	93		18	
127	32		16	
128	48		11	
129	78		15	
130	53		13	
131	39		12	
132	46		19	
133	47		21	
134	45		17	
135	60		14	
136	47		16	
137	40		8	
138	48		14	
139	52		22	
140	65		17	
141	63		19	
142	46		14	
143	54		19	
144	57		12	
145	57		16	
146	60		18	
147	55		19	
148	68		19	
149	43		13	
150	51		16	

151	50		17	
152	51		18	
153	60		19	
154	41		10	
Total	8357	5003	2612	1621
Total (por máscara)	13360		4233	

Nas tabelas I-6 e I-7 são mostrados os valores da função Golub usando, respectivamente, as regiões usando a máscara original e as regiões usando a máscara da região escondida.

Tabela I-6 - Valores da função Golub para as características das regiões usando a máscara original

Valores da função Golub para as características das regiões usando a máscara original	
<i>Característica</i>	<i>Valores</i>
Área normalizada	0.1407
Perímetro normalizado	0.0746
Raio efectivo	0.1438
Coordenada x do centróide	-0.0710
Coordenada y do centróide	-0.0181
Coordenada x relativa do centróide	-0.0699
Coordenada y relativa do centróide	-0.1142
Circularidade	0.1511
Perímetro efectivo	-0.1536
Coordenada x do centro de massa	-0.0705
Coordenada y do centro de massa	-0.0188
Distância Euclidiana entre o centro de massa e o centróide	0.0112
Média imagem filtrada	0.3148
Média imagem original	0.2684
Desvio padrão imagem filtrada	0.2340
Desvio padrão imagem original	0.1023
Máximo imagem filtrada	0.3536
Máximo imagem original	0.2421
Contraste imagem filtrada	0.2049
Contraste imagem original	0.1018
Média normalizada imagem filtrada	0.3227
Média normalizada imagem original	0.2771
Contraste normalizado imagem filtrada	0.2291
Contraste normalizado imagem original	0.1046

Tabela I-7 - Valores da função Golub para as características das regiões usando a máscara da região escondida

Valores da função Golub para as características das regiões usando a máscara da região escondida	
<i>Característica</i>	<i>Valores</i>
Área normalizada	0.1426
Perímetro normalizado	0.0382
Raio efectivo	0.1126
Coordenada x do centróide	-0.1260
Coordenada y do centróide	0.1592
Coordenada x relativa do centróide	-0.1757
Coordenada y relativa do centróide	-0.3910
Circularidade	0.1851
Perímetro efectivo	-0.1575
Coordenada x do centro de massa	-0.1258
Coordenada y do centro de massa	0.1589
Distância Euclidiana entre o centro de massa e o centróide	-0.0596
Média imagem filtrada	0.3093
Média imagem original	-0.0133
Desvio padrão imagem filtrada	0.0457
Desvio padrão imagem original	-0.1218
Máximo imagem filtrada	0.4090
Máximo imagem original	-0.0260
Contraste imagem filtrada	-0.1916
Contraste imagem original	-0.0824
Média normalizada imagem filtrada	-0.2814
Média normalizada imagem original	-0.1226
Contraste normalizado imagem filtrada	-0.1306
Contraste normalizado imagem original	-0.0645

Referências

- [1] Carlos S. Pereira, Hugo Fernandes, Ana Maria Mendonça, Aurélio Campilho, "Detection of Lung Nodule Candidates in Chest Radiographs", IbPRIA 2007, Part II, LNCS 4478, pp. 170-177, 2007
- [2] Paulo Mazzoncini de Azevedo-Marques, "Diagnóstico auxiliado por computador na radiologia", Radiologia brasileira, vol. 34, n.º5, São Paulo, Set/Out 2001
- [3] Radiological Society of North America, "Radiation Exposure in X-ray Examinations", disponível em http://www.radiologyinfo.org/en/safety/index.cfm?pg=sfty_xray&bhcp=1. Acesso em 10-05-2009
- [4] Arnold M.R. Schilham, Bram Van Ginneken, Marco Loog, "A computer-aided diagnosis system for detection of lung nodules in chest radiographs with an evaluation on a public database", Medical Image Analysis, 10 (2006), pp. 247-258
- [5] J. Toriwaki, Y. Suenaga, T. Negoro, T. Fukumura, "Pattern recognition of chest X-ray images", 1973, Computer Graphics and Image Processing 2, pp. 252-271
- [6] W. Lampeter, J. Wandtke, "Computerized search of chest radiographs for nodules", 1986, Investigative Radiology 21, pp. 384-390
- [7] M. L. Giger, K. Doi, H. Macmahon, "Image feature analysis and computer-aided diagnosis in digital radiography", 1988, Medical Physics. 15, pp. 158-166
- [8] M. L. Giger, K. Doi, H. Macmahon, C. E. Metz, Y. Yin, "Pulmonary nodules: computer-aided detection of pulmonary nodules in digital chest images", 1990, Radiographics 10, pp. 41-52
- [9] T. Matsumoto, H. Yoshimura, M. L. Giger, K. Doi, H. Macmahon, S. Montmer, T. Nakanishi,

"Potential usefulness of computerized nodule detection in screening programs for lung cancer: a pilot study", 1992, *Investigative Radiology* 27, pp. 471-475

[10] S. Lo, M. Freedman, J. Lin, S. Mun, "Automatic lung nodule detection using profile matching and back-propagation neural network techniques", 1993, *J Digit Imaging* 6, pp. 48-54

[11] H. Yoshida, X. W. Xu, T. Kobayashi, M. L. Giger, K. Doi, "Computer-aided diagnosis scheme for detecting pulmonary nodules using wavelet transform", 1995, *Proceedings of SPIE* 2434, pp. 621-626

[12] X. W. Xu, K. Doi, T. Kobayashi, H. Macmahon, M. L. Giger, "Development of an improved CAD scheme for automated detection of lung nodules in digital chest images", 1997, *Medical Physics* 24, pp. 1395-1403

[13] Bilgin Keserci, Hiroyuki Yoshida, "Computerized detection of pulmonary nodules in chest radiographs based on morphological features and wavelet snake model", *Medical Image Analysis*, 6 (2002), pp. 431-447

[14] P. Campadelli, E. Casiraghi, S. Columbano, "Lung segmentation and nodule detection in postero anterior chest radiographs", 2004, *Gruppo Italiano Ricercatori in Pattern Recognition*

[15] P. Campadelli, E. Casiraghi, D. Artioli, "A Fully Automated Method for Lung Nodule Detection from Postero-Anterior Chest Radiographs", 2006, *Medical Imaging*, Volume 25, Issue 12, pp. 1588-1603

[16] Junji Shiraishi; Feng Li; Kunio Doi, "Computer-aided diagnosis for improved detection of lung nodules by use of PA and lateral chest radiographs", *Acad Radiology*, 2007, Volume 14, Issue 1, pp. 28-37

[17] Tiago Guichard, "Detecção de núcleos de células em sequências de imagens de microscopia confocal", Julho de 2008

[18] Carlos S. Pereira, Ana Maria Mendonça, Aurélio Campilho, "Evaluation of contrast enhancement filters for lung nodule detection", *ICIAR 2007, LNCS 4633*, pp. 878-888, 2007

[19] T. R. Golub, D. K. Slonim, P. Tamayo, C. Huard, M. Gaasenbeek, J. P. Mesirov, H. Coller, M. L. Loh, J. R. Downing, M. A. Caligiuri, C. D. Bloomfield, E. S. Lander, "Molecular classification of cancer: class discovery and class prediction by gene expression monitoring", *Science*, vol. 286, pp. 531-537, 1999

- [20] António Augusto Varejão Teixeira de Sousa, "Análise e reconhecimento de imagem em cromatografia da camada fina", 2007
- [21] Sandrine Dudoit, Jane Fridlyand, Terence P. Speed, "Comparison of discrimination methods for the classification of tumors using gene expression data", Technical report #576, Junho 2000
- [22] Junji Shiraishi, Shigehiko Katsuragawa, Junpei Ikezoe, Tsuneo Matsumoto, Tekeshi Kobayashi, Ken-ichi Komatsu, Mitate Matsui, Hirsohi Fujita, Yoshie Kodera, Kunio Doi, "Development of a Digital Image Database for Chest Radiographs With and Without a Lung Nodule: Receiver Operating Characteristic Analysis of Radiologists' Detection of Pulmonary Nodules", January 2000, pp. 71-74
- [23] Shingo Kakeda, Katsumi Nakamura, Koji Kamada, Hideyuki Watanabe, Hajime Nakata, Shigehiko Katsuragawa, Kunio Doi, "Improved Detection of Lung Nodules by Using a Temporal Subtraction Technique", Radiology 2002, Volume 224, Number 1, pp. 145-151
- [24] Shunji Tsukuda, Atsuko Heshiki, Shigehiko Katsuragawa, Qiang Li, Heber Macmahon, Kunio Doi, "Detection of Lung Nodules on Digital Chest Radiographs: Potential Usefulness of a New Contralateral Subtraction Technique", Radiology 2002, Volume 223, Number 1, pp. 199-203
- [25] Bram Van Ginneken, Bart M. ter Haar Romeny, Max A. Viergever, Computer-Aided Diagnosis in Chest Radiography, "A Survey, IEEE Transactions on medical imaging", 2001, vol. 20, no. 12, pp. 1228-1241
- [26] Sérgio Eduardo de Almeida Mota, "Detection of Pulmonary Nodules Based on a Template-Matching Technique", FEUP, 2003
- [27] Martin Dolejsi, "Detection of Pulmonary Nodules from CT Scans", CTU-CMP-2007-05, 2007
- [28] P. Campadelli, E. Casiraghi, G. Valentini, "Lung nodules detection and classification", 2005, Proceedings of International Conference on Image Processing
- [29] P. Campadelli, E. Casiraghi, G. Valentini, "Vector Machines for Candidate Nodule Classification", 2005, Neurocomputing, Volume 68, pp. 281-288
- [30] H. Yoshida, S. Katsuragawa, Y. Amit, K. Doi, "Wavelet snake for classification of nodules and false positives in digital chest radiographs", 1997, Proceedings of the IEEE Engineering in

[31] Fernando M. Silva, "Máquinas de suporte vectorial e métodos de kernel", Março de 1999, IST de Lisboa

[32] R. P. W. Duin, P. Juszczak, P. Paclik, E. Pekalska, D. de Ridder, D. M. J. Tax, S. Verzakov, "PRTTools4 - A Matlab Toolbox for Pattern Recognition", Version 4.1, August 2007

[33] Richard O. Duda, Peter E. Hart, David G. Stork, "Pattern Classification", Second edition

[34] F. van der Heijden, R. P. W. Duin, D. de Ridder, D. M. J. Tax, "Classification, Parameter Estimation and State Estimation - An Engineering Approach using Matlab", John Wiley & Sons, Ltd, 2004

[35] H. Kobatake, M. Murakami, "Adaptative filter to detect rounded convex regions: iris filter", Proceedings of the 13th international conference of pattern recognition, volume 2, 1996, pp. 340-344

[36] António V. Sousa, Ana Maria Mendonça, Aurélio Campilho, "Chromatographic pattern classification", IEEE Transactions of Biomedical Engineering, vol. 55, no. 6, June 2008, pp. 1687-1696

[37] Nitesh V. Chawla, Kevin W. Bowyer, Lawrence O. Hall, W. Philip Kegelmeyer, "SMOTE: Synthetic Minority Over-Sampling Technique", Journal of Artificial Intelligence Research 16 (2002), pp. 321-357

[38] Chao Chen, Andy Liaw, Leo Breiman, "Using random forest to learn imbalanced data", pp. 1-12

[39] Marcus A. Maloof, "Learning when data sets are imbalanced and when costs are unequal and unknown", Workshop on learning from imbalanced data sets II, ICML, Washington DC, 2003

[40] João Francisco de Sousa Cardoso, "Predição da qualidade na indústria de fundição injectada", Porto, 2001